

En español

Filtrado digital neuronal difuso: caso MIMO

Juan Carlos García Infante¹, José de J. Medel Juárez²,
Juan Carlos Sánchez García³

RESUMEN

Los filtros identificadores multivariados (MIMO) son sistemas digitales adaptivos que cuentan con retroalimentación para que, de acuerdo a una función objetivo, ajusten su matriz de parámetros con la que se aproximan a la dinámica observable del sistema de referencia. Una forma de que un identificador cumpla con esas condiciones, es la de la lógica difusa por medio de sus mecanismos de inferencia que interpretan y seleccionan en una base de conocimiento la mejor matriz de parámetros. Estos mecanismos de selección mediante las redes neuronales permiten encontrar la respuesta con el mejor nivel de operación para cada cambio de estado (Shannon, 1948). En este artículo se considera en el modelo MIMO del filtrado digital, el proceso neuronal difuso para la estimación matricial de parámetros adaptiva, que se integra en el filtro de Kalman a través de la matriz de transición. Para ello se utilizó la red neuronal del tipo retropropagación en el mecanismo difuso, interpretando sus variables y sus respectivos niveles, seleccionando los mejores valores para ajustar automáticamente los valores de la matriz de transición. La simulación en Matlab presenta al filtrado digital neuronal difuso dando el seguimiento, observándose un funcional de error decreciente exponencialmente.

Palabras clave: filtro digital, control difuso, red neuronal, MIMO, adaptivo.

Recibido: noviembre 25 de 2009

Aceptado: enero 24 de 2011

Introducción

Una red neuronal artificial es un modelo computacional que imita un proceso natural como un sistema biológico, que tiene elementos de procesamiento llamados neuronas, como en el cerebro humano, todas ellas interconectadas, conformando una estructura de red neuronal (Nikola, 1996; Medel *et al.*, 2008). Una red neuronal difusa clasifica, busca y asocia información (Huang, *et al.*, 2006), dando un valor de respuesta correspondiente que esté de acuerdo con la señal deseada del proceso de referencia, construyendo el volumen de control descrito como

$$T_N = \{(Y(k), \hat{Y}(k))\}$$

donde $T_N : (Y_N \times \hat{Y}_N) \times T \rightarrow \{(Y(k), \hat{Y}(k)), \tau(k)\}_{k=1}^N$ dentro de los

¹ Ph.D., en Tecnología Avanzada y Ciencia Aplicada en el CICATA Legaria. Vinculado a SEPI, ESIME Culhuacán, México. jcnnet21@yahoo.com

² Ph.D., en ciencias en Control Automático en el CINVESTAV. Vinculado a CIC, México. jjmedelj@yahoo.com.mx

³ Ph.D., en Sistemas Digitales en la UAM Iztapalapa, México. Vinculado a SEPI, ESIME Culhuacán, México. jcsanchezgarcia@gmail.com

In English

Neural fuzzy digital filtering: multivariate identifier filters involving multiple inputs and multiple outputs (MIMO)

Juan Carlos García Infante⁴, José de J. Medel Juárez⁵,
Juan Carlos Sánchez García⁶

ABSTRACT

Multivariate identifier filters (multiple inputs and multiple outputs - MIMO) are adaptive digital systems having a loop in accordance with an objective function to adjust matrix parameter convergence to observable reference system dynamics. One way of complying with this condition is to use fuzzy logic inference mechanisms which interpret and select the best matrix parameter from a knowledge base. Such selection mechanisms with neural networks can provide a response from the best operational level for each change in state (Shannon, 1948). This paper considers the MIMO digital filter model using neuro fuzzy digital filtering to find an adaptive parameter matrix which is integrated into the Kalman filter by the transition matrix. The filter uses the neural network as back-propagation into the fuzzy mechanism to do this, interpreting its variables and its respective levels and selecting the best values for automatically adjusting transition matrix values. The Matlab simulation describes the neural fuzzy digital filter giving an approximation of exponential convergence seen in functional error.

Keywords: digital filter, fuzzy control, neural network, MIMO, adaptive digital system.

Recibido: November 25th 2009

Aceptado: January 24th 2011

Introduction

An artificial neural network is a computational model which imitates a natural process such as a biological system. It has processing elements called neurons as in the human brain which are all interconnected, thereby constructing a neural network structure (Nikola, 1996; Medel *et al.*, 2008). A fuzzy neural network classifies, searches for and associates information (Huang *et al.*, 2006), giving a specific value in accordance with a desired reference signal. It constructs control volume described as

$$T_N = \{(Y(k), \hat{Y}(k))\}$$

where $T_N : (Y_N \times \hat{Y}_N) \times T \rightarrow \{(Y(k), \hat{Y}(k)), \tau(k)\}_{k=1}^N$ within

⁴ Ph.D., Advanced Technology and Applied Science at the CICATA Legaria. Associated to SEPI, ESIME Culhuacán, Mexico. jcnnet21@yahoo.com

⁵ Ph.D., Science in Automatic Control at the CINVESTAV. Associated to CIC, Mexico. jjmedelj@yahoo.com.mx

⁶ Ph.D., Digital Systems at the UAM Iztapalapa, Mexico. Associated to SEPI, ESIME Culhuacán, México. jcsanchezgarcia@gmail.com

intervalos de membresía delimitados en la base de conocimiento (Schneider y Kandel, 1996).

membership intervals is delimited into a knowledge base (Schneider and Kandel, 1996).

Filtro neuronal difuso

Fuzzy neural filter

El conjunto de respuestas dentro de la base de conocimiento representa todas las posibles respuestas correctas del filtro (Gustafsson, 2000; Margaliot y Langholz, 2000; Zadeh, 1965) de acuerdo a una ley objetivo previamente definida por el proceso de referencia natural; el mecanismo de filtrado seleccionará la mejor respuesta de la base de conocimiento en cada estado empleando reglas difusas (if-then).

Responses set into the knowledge base represent all possible correct filter responses (Gustafsson, 2000; Margaliot and Langholz, 2000; Zadeh, 1965) in accordance with an objective law, previously defined by actual natural references. The filtering mechanism selects the best response from the knowledge base when the state changes, using fuzzy (if-then) rules. The neural fuzzy filter is based on a back-propagation algorithm because its parameters are dynamically updated (Ali, 2003; Amble, 1987; Haykin, 1996), having different levels for each iteration (Huang, Zhu and Siew, 2006) using error described as $E(k)$ (minimising it

El filtro neuronal difuso está basado en el algoritmo de retropropagación, ya que sus parámetros se actualizan dinámicamente (Ali, 2003; Amble, 1987; Haykin, 1996) y en diferentes niveles a cada iteración (Huang et al., 2006), en base al error descrito como $E(k)$ (reduciéndolo por medio del criterio

using $E(k) := (Y(k) - \hat{Y}(k)) \in R^{n \times 1}, n \in Z_+$ criterion in MIMO structure, this being the distance between the desired signal $Y(k)$

como $E(k) := (Y(k) - \hat{Y}(k)) \in R^{n \times 1}, n \in Z_+$, ésta es la estructura MIMO que es la diferencia entre la respuesta deseada $Y(k)$ y la salida del filtro actual $\hat{Y}(k)$ (García et al., 2008; Marcek, 2008). La figura 1 muestra el proceso del filtrado (Passino, 1998):

and actual filter output $\hat{Y}(k)$ (García et al., 2008; Marcek, 2008). Figure 1 shows the filtering (Passino, 1998).

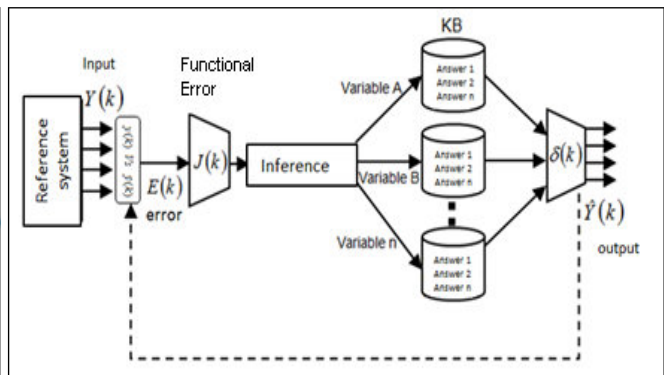
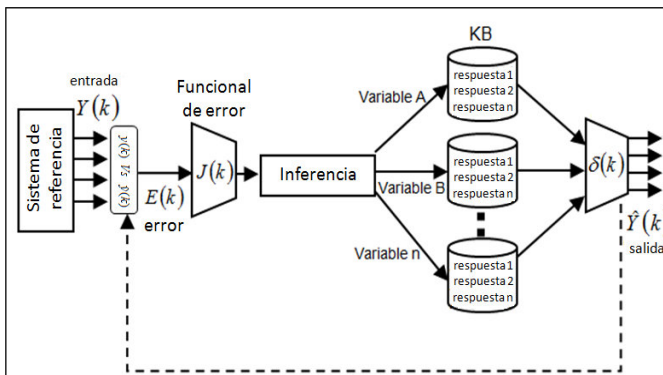


Figura 1. Proceso del filtrado neuronal

Figure 1. Neuron filter

El error ($E(k)$) está limitado en el intervalo $[0, \varepsilon]$ y ε es descrito

Error ($E(k)$) has a limit interval $[0, \varepsilon]$ and ε is described as being a

$$\inf\{|E(k)| : i, k \in Z_+\}$$

positive value in accordance with $\inf\{|E(k)| : i, k \in Z_+\}$ (i , is the index with k intervals) (Margaliot and Langholz, 2000)

como un valor positivo de acuerdo con donde i es el índice, con k intervalos (Margaliot y Langholz, 2000; Morales, 2002). Descrito de la forma: $\sup\{eig(E(K))\} \leq \{\gamma_i : \gamma_i > 0, \forall i \in Z_+\}$

(Morales, 2002). Described as: $\sup\{eig(E(K))\} \leq \{\gamma_i : \gamma_i > 0, \forall i \in Z_+\}$

, tal que $\inf\{\gamma_i\} \rightarrow |\lambda_*|$, donde $|\lambda_*| > 0$, $\sup\{\gamma_i\} \rightarrow |\lambda^*|$, $|\lambda^*| < 1$

, where $|\lambda_*| > 0$, $\sup\{\gamma_i\} \rightarrow |\lambda^*|$, $|\lambda^*| < 1$.

El filtro neuronal difuso está basado en los siguientes elementos, considerando los conceptos descritos en (Abraham, 1991; Ali, 2003; Gustafsson, 2000; Mamdani, 1974; Morales, 2002):

A neural fuzzy filter considers the following elements and concepts described in (Abraham, 1991; Ali, 2003; Gustafsson, 2000; Mamdani, 1974; Morales, 2002):

Entrada de inferencia difusa: en esta etapa la señal deseada $Y(k)$ desde el sistema de referencia a la entrada del filtro tiene una descripción en un sentido métrico (Ash, 1970).

Fuzzy inference input. Filter input has metric sense description during this desired signal stage from reference system $Y(k)$ (Ash, 1970);

Base de reglas: son intervalos de rango dinámico que hacen una

Rule base: This is an inference set of filter input interprets using

En español

interpretación o inferencia en la entrada del filtro empleando el conector lógico binario conocido como Si (IF).

Mecanismo de inferencia: es la acción experta con respecto a la base de reglas, conocida como consecuencia para seleccionar la función de membresía correspondiente descrita como $\hat{A}(k)$ por medio del conector lógico binario Entonces (THEN) (Yamakawa, 1989).

Función de activación: ésta es la etapa de filtrado, la cual es la respuesta digital del filtro transformada en una respuesta natural. Es el valor que tiene la mejor aproximación a la señal deseada, sustentada en una base de conocimiento definida previamente.

Realimentación natural: finalmente, el proceso de filtrado toma el valor lingüístico correcto y actualiza los parámetros del filtro a una condición natural con respecto al sistema de referencia,

considerando la diferencia de error existente entre $Y(k)$ y $\hat{Y}(k)$ de forma dinámica, utilizando el criterio descrito como funcional de error $J(k)$ (es la matriz del funcional del error que describe la relación de convergencia entre el valor observado real y su estimación. En forma recursiva es:

$$J(k) = \frac{1}{k_1 k_2} [E(k_1)E(k_2)^T + (k_1 - 1)(k_2 - 2)J(k - 1)_{1,2}] \quad k_1, k_2 \in Z_+$$

El funcional de error es una matriz cuadrática dimensional donde $\lim_{k \rightarrow \infty} |tr(J(k))| \rightarrow m$ es la matriz de referencia y el sistema es convergente a m si $0 < \{tr(J(k))\} < 1$. El funcional es expresado con respecto al segundo momento de probabilidad, teniendo un valor ínfimo descrito en (1).

$$J_{\min} = \inf_N \{ \min J(Y_0, \hat{Y}) \} \quad (1)$$

En resumen el filtrado neuronal difuso tiene previamente toda la información requerida dentro de su base de conocimiento para seleccionar la respuesta correspondiente al valor de la señal deseada en la entrada del filtro. Primero, el proceso de filtrado emplea las reglas difusas establecidas para hacer una inferencia o interpretación del vector de la señal deseada expresada como $Y(k)$ (Takagi y Sugeno, 1986). El mecanismo del filtro selecciona dentro de su estructura de datos la variable activada y su nivel correspondiente (la variable, por ejemplo, puede ser A: temperatura, B: velocidad y C: presión, y su respectivo nivel: bajo, medio y alto); entonces el mecanismo de reglas selecciona el parámetro correspondiente $\hat{A}(k)$ para ajustar el filtro y dar el vector de respuesta correcto $\hat{Y}(k)$ a la entrada del filtro (Rajem y Gopal, 2006).

In English

binary logic IF connector;

Inference mechanism: This is the expert consequence regarding the rule base for selecting membership function described as $\hat{A}(k)$ using the logic THEN connector (Yamakawa, 1989);

Activation function: This is the response filter stage transformed into a natural response. It is the best desired signal approximation value, previously described in the knowledge base; and

Natural updating: The filter process acquires the correct linguistic value and updates filter parameter values to a natural condition regarding the reference system, considering error difference

between $Y(k)$ and $\hat{Y}(k)$ dynamically using functional error criterion $J(k)$ (being the functional error matrix describing the real observed convergence value relationship and its estimation. In recursive form, this is:

$$J(k) = \frac{1}{k_1 k_2} [E(k_1)E(k_2)^T + (k_1 - 1)(k_2 - 2)J(k - 1)_{1,2}] \quad k_1, k_2 \in Z_+$$

Functional error is a dimensional quadratic matrix where $\lim_{k \rightarrow \infty} |tr(J(k))| \rightarrow m$, having convergence in m if $0 < \{tr(J(k))\} < 1$. The function is expressed in accordance with the second probability moment, its infimum value being described in (1).

$$J_{\min} = \inf_N \{ \min J(Y_0, \hat{Y}) \} \quad (1)$$

The neural fuzzy filter needs the knowledge base to select the corresponding response in accordance with the desired signal. Filtering first uses established fuzzy rules to infer or interpret the

desired signal vector expressed as $Y(k)$ (Takagi and Sugeno, 1986). The filter mechanism selects the correct variable in its data form and selects the level (the variable could be A temperature, B velocity or C pressure, respective levels being low, medium or high). The rules mechanism then selects the correspond-

ing parameter $\hat{A}(k)$ to adjust the filter, thereby giving the correct vector response $\hat{Y}(k)$ at filter output (Rajem and Gopal, 2006).

Propiedades de la matriz de parámetros

Para hacer la descripción de un filtro neuronal difuso en su forma multivariable con variaciones de tiempo, el parámetro

$\hat{A}(k) \subseteq R_{[0,1]}^{m \times n}$ debe cumplir condiciones de acuerdo a la matriz de transición:

Tiene restricciones en su operación de acuerdo a las propiedades dinámicas de la matriz de transición: 1) $\ln(\Phi(k)) < [\infty]$, 2)

$\ln(\Phi(k)) > [0]$, 3) $\ln(\Phi(k))k^{-1} < I$. Donde $[\infty]$, $[0]$ y

I son las matrices descritas como infinito, nula y la identidad de forma respectiva. El estimador por medio de la matriz de transición es descrito en (2).

$$\hat{A}(k - k_0) = \ln \Phi(k) (\ln \phi(k_0)(k - k_0))^{-1} \quad (2)$$

Cuyas velocidades de cambio están acotadas dentro de la función de transición (3).

$$\ln(\Phi(k)) \leq \ln \Phi(k_0)(k - k_0)^T, \quad \ln \Phi(k_i) \leq \ln(\Phi(k_i - I)(k_i - k_i - I)^T \quad (3)$$

La matriz de transición se encuentra acotada en $[0] \leq \Phi(k_i) \leq I$.

De acuerdo al valor del $\ln \Phi(k_0)$, la matriz de parámetros estimada cumple con la desigualdad (4).

$$\hat{A}(k - k_0) \leq \ln \Phi(k_0) \quad (4)$$

Y el identificador de Kalman usando a (4), se presenta en (5).

$$\hat{X}_k = \hat{A}(k - k_0) \hat{X}_{k-1} + K_k \hat{w}_k \quad (5)$$

Donde K_k es la matriz de ganancias de Kalman descrita por la varianza del error de identificación definido por la diferencia de la señal deseada respecto de la señal de salida del filtro, descrito

de manera recursiva, y \hat{w}_k es el ruido que excita al proceso de referencia.

Resultados

La simulación del filtro neural difuso MIMO se realiza considerando al filtro de Kalman (Haykin, 1996) con una matriz de transición descrita por la base del conocimiento de acuerdo al criterio del funcional del error (Ash, 1970). Los tiempos de evolución que delimitan un sistema de tipo *soft* (estadístico) implantado en una computadora con procesador AMD Sempron 3100+ con

Parameter matrix properties

Multivariate neural fuzzy filter parameters $\hat{A}(k) \subseteq R_{[0,1]}^{m \times n}$ must fulfil conditions in accordance with the transition matrix:

It has dynamic transition matrix restriction operation: 1)

$$\ln(\Phi(k)) < [\infty], \quad 2) \quad \ln(\Phi(k)) > [0], \quad 3) \quad \ln(\Phi(k))k^{-1} < I$$

where $[\infty]$, $[0]$ and I are a matrix described as infinity, null and identity, respectively. The estimator is described using the transition matrix in (2):

$$\hat{A}(k - k_0) = \ln \Phi(k) (\ln \phi(k_0)(k - k_0))^{-1} \quad (2)$$

Change speed is limited within transition function (3):

$$\ln(\Phi(k)) \leq \ln \Phi(k_0)(k - k_0)^T, \quad \ln \Phi(k_i) \leq \ln(\Phi(k_i - I)(k_i - k_i - I)^T \quad (3)$$

The transition matrix is bounded in $[0] \leq \Phi(k_i) \leq I$.

In accordance with the value for $\ln \Phi(k_0)$, the estimated parameter matrix complies with the difference in (4):

$$\hat{A}(k - k_0) \leq \ln \Phi(k_0) \quad (4)$$

The Kalman filter (5) considered (4):

$$\hat{X}_k = \hat{A}(k - k_0) \hat{X}_{k-1} + K_k \hat{w}_k \quad (5)$$

where Kalman matrix gain (K_k) is a functional identification error, defined by the second probability moment between the

desired signal and output recursive filter signal and, \hat{w}_k represents noise.

Results

The MIMO neural fuzzy filter considered Kalman filter structure (Haykin, 1996), the transition matrix being based on knowledge according to functional error criteria (Ash, 1970). A statistical software system considered evolution times bounded by PC with AMD Sempron 3100+ processor performance at k intervals, average evolution time being $0.004 \text{ sec} \pm 0.0002 \text{ sec}$.

En español

intervalos k , teniendo un promedio en el tiempo de evolución de $0,004 \text{ seg} \pm 0,0002 \text{ seg}$. El sistema ARMA básicamente representa un sistema de referencia en un espacio de estados discreto expresado por la diferencia de primer orden en (6).

$$X(k+1) = A(k)X(k) + W(k) \quad (6)$$

Y su salida es descrita en (7).

$$Y(k) = X(k) + V(k) \quad (7)$$

Donde $X(k), Y(k), W(k), V(k) \in \mathbb{R}^{n \times 1}$, $A(k) \in \mathbb{R}^{m \times n}$

$X(k)$ es el vector de estados internos, $A(k)$ es la matriz de parámetros, $W(k)$ es el conjunto de ruidos que perturban al sistema, $y(k)$ es el conjunto de vectores de señales deseadas del sistema de referencia a la entrada del filtro y $V(k)$ es el vector de ruidos de salida. Los diferentes niveles de operación están descritos para operar con respecto al funcional del error¹. El proceso de filtrado establece para cada variable una descripción lingüística expresada por los niveles: bajo, medio y alto. La figura 2 muestra la estimación de la matriz de parámetros descrita en este caso por una matriz $\hat{A}(k) \in \mathbb{R}^{2 \times 2}$.




Figura 2. Estimación de la matriz de parámetros

De acuerdo a la estimación de parámetros descrita con la variable $\hat{A}(k)$, la figura 3 muestra la proyección de los niveles de respuesta a la salida del filtro descrita con la variable $\hat{Y}(k)_1$ respecto de la señal deseada del sistema de referencia $Y(k)_1$. En cuanto a los valores de $\hat{A}(k)$, la figura 4 muestra la proyección de los niveles a la salida del filtro con respecto a la variable $\hat{Y}(k)_2$ y a la señal deseada del sistema de referencia descrita como $Y(k)_2$.

In English

This paper used the first order differential and discrete ARMA model (6) to represent a reference system.

$$X(k+1) = A(k)X(k) + W(k) \quad (6)$$

Output (7):

$$Y(k) = X(k) + V(k) \quad (7)$$

Where $X(k), Y(k), W(k), V(k) \in \mathbb{R}^{n \times 1}$, $A(k) \in \mathbb{R}^{m \times n}$

$X(k)$ was the internal state vector, $A(k)$ represented matrix parameters, $W(k)$ was vector noise within the system, $Y(k)$ was the reference vector desired system signal at filter input and $V(k)$ was output vector noise.

Operational levels were described for operation regarding functional error. Filtering gives each variable a linguistic description expressed as low, medium and high levels. Figure 2 shows matrix parameter estimation given by $\hat{A}(k) \in \mathbb{R}^{2 \times 2}$.




Figure 2. Matrix parameter estimation

Considering matrix parameter estimation $\hat{A}(k)$ in (5), Figure 3 shows projected response levels at filter output $\hat{Y}(k)_1$ with desired signal $Y(k)_1$. Figure 4 presents projection variables $\hat{Y}(k)_2$ and $Y(k)_2$.

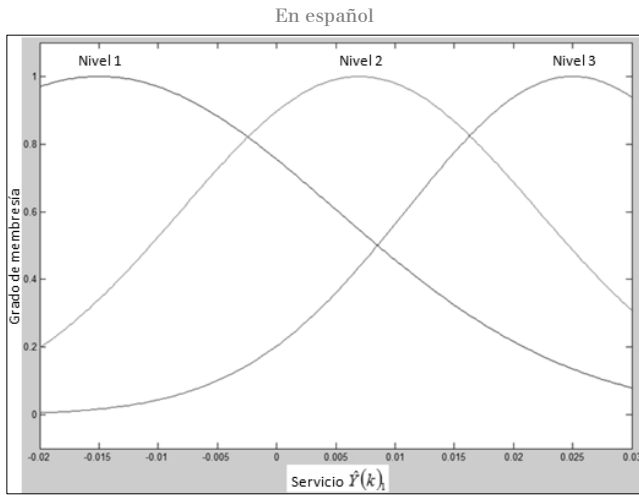


Figura 3. Niveles de operación de $Y(k)_1$

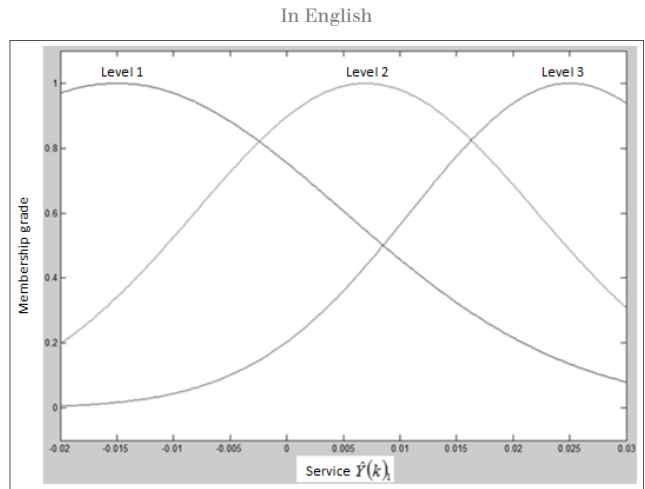


Figure 3. $Y(k)_1$ operational levels

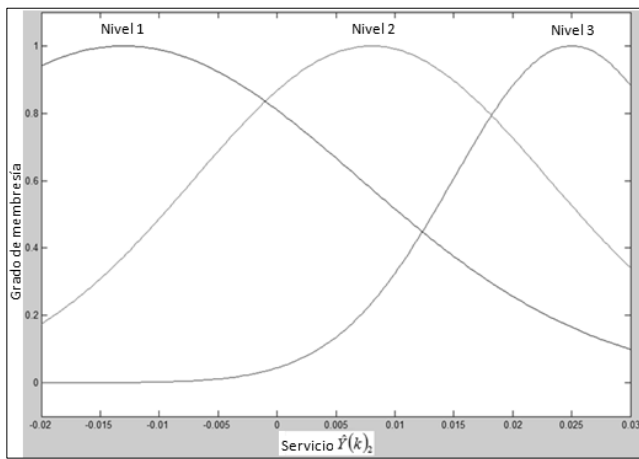


Figura 4. Niveles de operación de $Y(k)_2$




Figure 4. $Y(k)_2$ operational levels.

La figura 5 muestra la estimación de $\hat{Y}(k)_1$, con respecto a la señal deseada $Y(k)_1$, a la entrada del filtro, y la figura 6 la estimación de $\hat{Y}(k)_2$, con respecto a la señal deseada $Y(k)_2$ a la entrada del filtro.

Figures 5 and 6 show identification $\hat{Y}(k)_1$ and desired signal $Y(k)_1$ and, $\hat{Y}(k)_2$, with $Y(k)_2$, respectively.




Figura 5. Identificación de la salida del filtro con respecto a $y(k)_1$
Figure 5. Output signal identification $\hat{Y}(k)_1$ and $Y(k)_1$




Figura 6. Identificación de la salida del filtro con respecto a $Y(k)_2$
Figure 6. Output signal identification $\hat{Y}(k)_2$ and $Y(k)_2$

En español

In English

La figura 7 exhibe el histograma de $\hat{Y}(k)_1$, y de la señal deseada $Y(k)_1$, y la figura 8 el histograma de $\hat{Y}(k)_2$, y de la señal deseada $Y(k)_2$.

Figures 7 and 8 show the histogram for $\hat{Y}(k)_1$ and desired signal $Y(k)_1$ and the histogram for $\hat{Y}(k)_2$, and $Y(k)_2$, respectively.





Figura 7. Histogramas de $Y(k)_1$ y $\hat{Y}(k)_1$ respectivamente.

Figure 7. Histogram $Y(k)_1$ and $\hat{Y}(k)_1$.





Figura 8. Histogramas de $Y(k)_2$ y $\hat{Y}(k)_2$ respectivamente.

Figure 8. Histogram $Y(k)_2$ and $\hat{Y}(k)_2$.

La figura 9 revela la señal de error natural descrita como $E(k)$ de acuerdo a cada señal deseada y la diferencia con la señal de salida respectiva; y la figura 10, la minimización de la señal de error natural descrita como $J(k)$ que es la matriz del funcional del error de acuerdo a la figura 9.

Figure 9 shows the natural error signal described by $E(k)$. Figure 10 shows the minimisation of the natural error signal described as $J(k)$, i.e. the functional error matrix in accordance with Figure 9.

Según el análisis de los resultados, el tiempo de evolución de la respuesta del filtro es menor que el tiempo de cambio de estado del proceso de referencia propuesto con el valor 0,09 seg, delimitado por el procesador, de acuerdo a la condición descrita en (7). El tiempo de convergencia es de 0,0862 seg, el cual es menor que la condición de tiempo de evolución de la referencia descrito como LD_{max} (García et al., 2008), de acuerdo a las propiedades descritas en las definiciones de este trabajo.

Filter response evolution time was less than the proposed 0.09 sec reference time state change delimited by the processor, considered in (7). Convergence time was 0.0862 sec. which was less than the LD_{max} evolution time described in (García et al., 2008).

En español




Figura 9. Señal de error natural.

In English




Figure 9. Natural error signals.




Figura 10. Funcional de error.




Figure 10. Functional error.

Conclusiones

En el artículo se describe al filtrado digital neural difuso multivariable (MIMO *Multiple Inputs and Multiple Outputs*), aplicado a sistemas dinámicos. Se realiza un análisis de su operación como un filtro adaptivo en función del error de identificación por medio de la matriz de transición dentro del filtro de Kalman. Para la selección adaptiva de la matriz de parámetros se consideró como herramienta el proceso formado por la red neuronal de retropropagación con los mecanismos difusos de selección de la matriz de parámetros, describiendo con la simulación el mecanismo de inferencia adaptiva, el cual clasifica y deduce las respuestas del filtro de acuerdo a la señal deseada y basada en el criterio de error, para seleccionar los valores de los pesos de la matriz de transición dentro del filtro identificador.

Se establece cómo construir y caracterizar las funciones de membresía de la base de conocimiento descrita en forma probabilística con el conjunto de reglas de decisión, integrando la arquitectura de la red neuronal de retropropagación para la selección automática de los parámetros de la matriz de transición. Los resultados se mostraron de forma ilustrativa, describiendo a la salida del filtro como $\hat{Y}(k)$,

con respecto a la señal deseada expresada como $Y(k)$.

Conclusions

This paper has described a multivariable neural fuzzy digital filter (having multiple inputs and multiple outputs - MIMO) applied to dynamic systems. Its operational adaptive conditions were analysed based on functional error identification and transition matrix within Kalman filter structure in which a back-propagation model integrated into fuzzy mechanisms enabled parameter selection. In simulation, the adaptive inference mechanism classified and deduced filter response in accordance with the desired signal, selecting transition matrix weighting for identification requirements.

Characterising and constructing membership functions from the probabilistic knowledge base as a set of decision rules led to integrating neural network architecture by automatically selecting parameters. The results illustratively described filter output

$\hat{Y}(k)$, $Y(k)$ (see Figures 5 and 6). Natural error (see Figure 9)

and functional error $J(k)$ (see Figure 10) showed the convergence levels. Future work will consider evolutionary properties for estimation instead of fuzzy logic.

En español

In English

sada como $Y(k)_1$ como se ve en la figura 5, así como $\hat{Y}(k)_2$ y $Y(k)_2$ en la figura 6, minimizando el error natural (figura 9) y el funcional del error $J(k)$ (figura 10). Como trabajo futuro se necesita ver el proceso de estimación con un sistema evolutivo, y comparar sus con los actuales.

Referencias / References

- Abraham, K., *Fuzzy Expert Systems.*, Florida, CRC Press, 1991.
- Ali, H.S., *Fundamentals of Adaptive Filters.*, New Jersey, John Wiley & Sons, 2003.
- Amble, T., *Logic Programming and Knowledge Engineering.*, USA, Addison Wesley, 1987.
- Ash, R., *Real Analysis and Probability.*, USA, Ed. Academic Press, 1970.
- García, J.C., Medel, J. J., Guevara, P., RTFDF Description for ARMA Systems., *WSEAS Journal: Transactions on Systems and Control*, Vol. 2, Issue 10, 2007, pp. 491-496.
- García, J.C., Medel, J.J., Guevara, P., Filtrado Digital Difuso en Tiempo Real., *Revista Computación y Sistemas*, Vol. 11, No. 4, 2008, pp. 390-401.
- García, J.C., Medel, J.J., Guevara, P., Real-time neuro-fuzzy digital filtering: Approach., *Computer and Simulation in Modern Science*, WSEAS press selected papers, Vol. 1, 2008, pp. 122-125.
- Haykin, S., *Adaptive Filtering.*, USA, Prentice Hall, 1996.
- Huang, G., Zhu, K., Siew, C., Real-Time Learning Capability of Neural Networks., *IEEE Transactions on Neural Networks*, Vol. 17, 2006, pp. 863-878.
- Gustafsson, F., *Adaptive Filtering and Change Detection.*, Inglaterra, John Wiley and Sons, 2000.
- Mamdani, E., Applications of Fuzzy Algorithms for Control of Simple Dynamic Plant., *Proc. IEEE*, Vol. 121, 1974, pp. 1585-1588.
- L. Manuel, *Teoría de la Medida e Integral de Lebesgue*, Universidad Nacional del Rosario, 2003.
- Margaliot, M., Langholz, G., *New Approaches to Fuzzy Modeling and Control Design and Analysis.*, Singapore, World Scientific, 2000.
- Medel, J.J., Guevara, P., *Caracterización de Filtros Digitales en Tiempo-real para Computadoras Digitales.*, *Computación y Sistemas*, Vol. VII, No. 3, 2004.
- Medel, J.J., García, J.C., Guevara, P., Real-time Fuzzy Digital Filters (RTFDF) Properties for SISO Systems., *Automatic Control and Computer Sciences*, AVT, Vol. 42, No. 1, 2008, pp. 26-34.
- Medel, J.J., García, J.C., Sánchez, J.C., Real-time Neuro-Fuzzy Digital Filtering: Basic Concepts., *WSEAS Transactions on Systems and Control*, 2008, Vol. 3, Issue 8, pp. 654-663.
- Marcek, D., *Stock Price Forecasting: Statistical, Classical and Fuzzy Neural Networks.*, *Modeling Decisions for Artificial Intelligence*, Springer Verlag, 2004, pp. 41-48.
- Morales, G., *Introducción a la Lógica Difusa.*, México, Cinvestav-IPN, 2002.
- Nikola, K., *Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering.*, Hong Kong, The MIT Press, 1996.
- Passino, K.M., *Fuzzy Control*, USA, Addison Wesley, 1998.
- Rajen, B., Gopal, M., *Neuro-Fuzzy Decision Trees.*, *International Journal of Neural Filters*, Vol. 16, 2006, pp. 63-68.
- Shannon, M., *A Mathematical Theory of Communication.*, *Bell Systems Technical Journal*, Vol.27, 1948, pp. 379-423 and pp. 623-656.
- Schneider, M., Kandel, A., *Fuzzy expert systems tools.*, Inglaterra, John Wiley & Sons, 1996.
- Takagi, T., Sugeno, M., *Fuzzy Identification of Systems and its Applications to Modelling and control.*, *IEEE Transactions and Systems, man, and cybernetics*, Vol. 15, 1986, pp. 116-132.
- Yamakawa, F., *Fuzzy Neurons and Fuzzy Neural Networks.*, 1989.
- Zadeh, L., *Fuzzy Sets.*, *Information and control*, Vol. 8, 1965, pp. 338-353.